

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Rene Zamostni

**SIMULACIJSKO MODELIRANJE ZA
POTREBE FINANCIJSKE ANALIZE
ISPLATIVOSTI PROJEKTA**

ZAVRŠNI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Rene Zamostni

Matični broj: 43358/14–R

Studij: Poslovni sustavi

SIMULACIJSKO MODELIRANJE ZA POTREBE FINANCIJSKE
ANALIZE ISPLATIVOSTI PROJEKTA

ZAVRŠNI RAD

Mentor:

Mundar Dušan, univ. spec. actuar. math., pred.

Varaždin, srpanj 2018.

Rene Zamostni

Izjava o izvornosti

Izjavljujem da je moj završni rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor/Autorica potvrdio/potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Cilj rada je izrada modela u tabličnom kalkulatoru MS Excelu koji analizirajući prethodnih 5 godina poslovanja poduzeća, kroz financijske izvještaje bilanci, računa dobiti i gubitka te izvještaja o novčanim tijekovima daje ocjenu isplativosti ulaganja u poduzeće. Model sadrži analizu promjena stavaka tih izvještaja kroz godine i daje projekciju poslovanja na sljedećih 5 godina koristeći simulacije temeljene na slučajnim brojevima.

Podaci iz prethodnih godina poslovanja poduzeća korišteni su kao osnova za simulacije koje projiciraju poslovanje u sljedećih 5 godina. Rezultat projekcije su financijski izvještaji i neto novčani tok kroz narednih 5 godina poslovanja, iz kojeg se procjenjuje vrijednost poduzeća, a time i dionice, kao dijela poduzeća. Ta procjena može poslužiti kao procjena isplativosti kupovine dionice.

Simulacija je izrađena Monte Carlo metodom, uz korištenje slučajnih brojeva generiranih Excelovim formulama na temelju povijesnih vrijednosti. Dobiveni rezultati prikazani su u financijskih izvještajima, a najvažnije stavke prikazuju se dodatno grafički.

Model prikazuje poslovanje poduzeća Atlantska Plovidba d.d., a rad se osvrće i na specifične pojave vezane uz poslovanje u brodarskom prijevozu.

Ključne riječi: simulacija, simulacijsko modeliranje, Atlantska Plovidba, model, financijski izvještaji

Sadržaj

Sadržaj	iii
1. Uvod	1
1.1. Atlantska plovidba.....	2
1.2. Baltic Dry Index	2
2. Metode i tehnike rada	6
3. Model i projekcija poslovanja Atlantske plovidbe	9
3.1. Sadržaj modela	9
3.2. Pretpostavke i ulazni podaci modela	15
3.3. Analiza postotnih promjena.....	16
3.4. Postavke simulacije	21
3.5. Rezultati simulacije i tumačenje rezultata	23
3.6. Dijagram tijeka simulacije.....	27
4. Zaključak	28
Popis literature.....	29
Popis slika	31
Popis tablica	32
Prilog	33

1. Uvod

U ovom radu prikazati ću model ocjene financijske isplativosti ulaganja u dionice poslovnog sustava poduzeća Atlantska plovidba d.d. Model će se temeljiti na analizi i projekcijama financijskih izvještaja: bilance, računa dobiti i gubitka i izvještaja o novčanim tokovima. S internetskih stranica Zagrebačke burze, te portala anicazna.com (urednik: Krešimir Jušinski) preuzeo sam kvartalne financijske izvještaje za razdoblje od 2013. do 2017. godine. Analizom promjena koje su se događale iz godine u godinu i utjecaja promjena stavaka izvještaja na druge stavke sastavio sam model za predviđanje financijskih izvještaja za narednih 5 godina. Naglasak modela je na novčanim tokovima – slobodnom novčanom toku i procijeni vrijednosti dionice na temelju neto sadašnje vrijednosti očekivanih budućih novčanih tokova.

Kroz obradu teme upoznajemo se s financijskim izvještajima i značajnim pokazateljima koji se koriste kod izrade velikog broja financijskih projekata, iste je bitno razumjeti i znati koristiti kako bi se mogla ocijeniti isplativost projekta.

Izrada simulacija korištenjem slučajnih varijabli može se koristiti u različitim poslovnim situacijama. Model koji je prikazan u radu samo je jedan način korisne upotrebe simulacija. Izrada Simulacijskog modela u radu rađena je u tabličnom kalkulatoru MS Excel.

Na početku rada ukratko je prikazana povijest i način poslovanja Atlantske plovidbe. S obzirom da je poslovanje brodarskih poduzeća uvelike uvjetovano Baltic Dry Indexom, on je također objašnjen u posebnom poglavlju. Nakon uvodnih poglavlja objašnjene su metode i tehnike koje sam koristio kod izrade rada i primjera u tabličnom kalkulatoru. Naglašene su bitne formule i postupci kojima su izrađeni dijelovi modela. Središnji dio rada prikazuje podatke koji ulaze u model, njihovu analizu i kako su oni korišteni u daljnjoj simulaciji. Dio ulaznih podataka ne ulazi u simulaciju zbog svoje specifičnosti ili zbog načina na koji je simulacija postavljena. Takve iznimke su posebno objašnjene, jer njihovo izdvajanje iz ulaznih podataka modela uvelike utječe na krajnji rezultat. Rad završava tumačenjem rezultata dobivenih simulacijom, te zaključkom u kojem se ukratko osvrćem na izrađeni model i znanja koja sam koristio i stekao u izradi.

1.1. Atlantska plovidba

Brodarsko poduzeće Atlantska plovidba jedno je od najstarijih poduzeća te vrste na ovim prostorima. Poslovanje Atlantske plovidbe kroz godine je imalo određenih problema, većinom izazvanim padom vozarina (više o tome u poglavlju o Dry Baltic Indexu) u 2013., 2014. i 2016. godini, međutim već u 2018. godini cijena dionica raste s otprilike 100 kn (2016.) do više od 400 kuna.

Atlantska plovidba osnovana je 1955. u Dubrovniku. Osnovna djelatnost Atlantske plovidbe je prijevoz raznovrsnog tereta u slobodnoj plovidbi svjetskim morima. Deset godina nakon osnivanja flota Atlantske plovidbe imala je 20 brodova. Njihova ukupna nosivost bila je 183.000 tona. Dvadeset godina kasnije nosivost flote iznosila je 31.000 tona. Od 1995. godine tvrtka posluje kao dioničko društvo. Osim brodarskim prijevozom tereta tvrtka se bavi i hotelijerstvom, trgovanjem nekretninama i raznim turističkim djelatnostima (prema hr.wikipedia.org, 2018.)

Promatrajući vrijednost dionica na stranicama Zagrebačke burze od najstarijeg dostupnog datuma (početak 2008.) do 2018. godine otkrivamo kako su dionice 2008. bile izrazito visoke vrijednost – više od 1000. kuna. Međutim s dolaskom krize u godinama od 2011. do 2016. njihova vrijednost drastično je pala, održavši se jedva iznad 100 kuna po dionici. Od 2016. godine vrijednost ponovno počinje rasti, početkom 2018. prelazi i 600 kuna po dionici, međutim sredinom 2018. pada na otprilike 470 kuna. Vrijednost ovih dionica izrazito je jako uvjetovana političkim događajima u svijetu, u korelaciji s Dry Baltic Indexom, navodi uk.businessinsider.com (2018).

1.2. Baltic Dry Index

S obzirom da su mnoge promjene navedene u sljedećim poglavljima rada vezane za Baltic Dry Index potrebno je izvršiti laganu digresiju te ukratko pojasniti taj pojam. Dry Baltic Index je indeks prema kojem se računaju cijene brodarina. Te cijene brodarina od presudne su važnosti za poslovanje svih brodoprijevoznčkih kompanija jer o njima ovisi koliko mogu zaraditi na prijevozu tereta. Isti je slučaj i kod Atlantske plovidbe.

Prema investopedia.com Baltic Dry Index je trgovački i prijevoznčki indeks koji je kreirala Baltic Exchange mjenjačnica. On služi za mijenjanje cijena transporta kod različitih materijala. Baltic Exchange komunicira direktno s brokerima najvećih brodoprijevoznčkih kompanija koji predaju vozarine (cijene prijevoza) na svojim najvećim rutama. Baltic Dry Index nastaje kombinacijom triju indeksa: Capesize, Panamax i Supramax koji se odnose na različite veličine brodova.

Prema en.wikipedia.org Baltic Dry Index prvi put je izdan u siječnju 1985. godine od strane Baltic Exchange svjetske mjenjačnice iz Londona, a nastaje na temelju dnevnih volumena prijevoza obavljenih na sljedećim rutama:

Capesize indeks:

C8_14	Gibraltar/Hamburg preko Atlantika
C9_14	Mediterran prema Kini/Japanu
C10_14	Kina-Japan kružno preko Pacifika
C14	Kina-Brazil kružno
C16	Kina preko Australija/Indonezije ili Južne Afrike ili Brazila ili Zapadne obale SAD-a, do Europe

Panamax indeks:

P1A_82	Skaw-Gibraltar transatlantska ruta kružno
P2A_82	Skaw-Gibraltar do Južne Koreje preko Taiwana
P3A_82	Korea i Taiwan kružno po Pacifiku
P4_82	Korea i Taiwan do Skaw-Gib
P6_82	Deli Spore ili Busan kružno preko Atlantika

Supramax indeks:


S1B_58	Canakkale preko Mediterana ili Crnog mora do Kine ili Južne Koreje
S1C_58	Zapadna obala SAD-a do Kine i Južnog Japana
S2_58	Sjeverna Kina do Australije
S3_58	Sjeverna Kina do Zapadne Afrike
S4A_58	Zapadna obala SAD-a do Skaw-Passero
S4B_58	Skaw-Passero do Zapadne obale SAD-a
S5_58	Zapadna Afrika preko Južne Amerike do sjeverne Kine
S8_58	Južna Kina preko Indonezije do Indije
S9_58	Zapadna Afrika preko Istočne obale Južne Amerike do Skaw-Passero
S10_58	Južna Kina do Indonezije i natrag

„Skaw“ odnosi na sjeverni vrh Danske, a Passero južnu obalu Italije (prema slideshare.net).

Osim što služi za izračun cijena prijevoza tereta, Baltic Dry Index također je i odličan pokazatelj stanja tržišta – ponude i potražnje, za investitore koji ga znaju koristiti. Naime promatrajući promjene Baltic Dry Index-a, te indeksa čijom kombinacijom on nastaje, moguće

je odrediti kolika je potražnja na kojem tržištu za npr. sirovinama određenog tipa ili pak već izrađenim proizvodima ili poluproizvodima. Sirovine i poluproizvodi nose puno manju razinu špekulacije pri svome prijevozu, stoga su promjene Baltic Dry Index-a umjerene i bez skokova, dok je kod npr. elektroničke robe ili nekih drugih gotovih proizvoda prisutna veća razina špekulacija, te je moguće da indeksi ubrzano rastu ili padaju. Ovakve promjene investitori mogu koristiti da prepoznaju ili predvide promjene tržišta i smjer njegovog razvoja.

Prema uk.businessinsider.com Baltic Dry Index možemo promatrati kao jednog od glavnih indikatora globalne trgovine i ekonomskog stanja. Sljedeći grafikon prikazuje Baltic Dry Index u odnosu na obujam globalne trgovine.



Slika 1: Graf s prikazom Baltic Dry Index-a i Obujma globalne trgovine. (izvor: Thompson Datastream, Capital Economics, preuzeto s <http://uk.businessinsider.com/baltic-dry-index-falls-to-lowest-level-in-history-2016-1>, dostupno 11.7.2018.)

Na grafu je vidljivo da su dvije navedene stavke većinom izrazito blizu, iz čega zaključujemo da su one na neki način povezane. Također vidimo da je od 2010. godine do 2016. godine Baltic Dry Index izrazito pao. Businessinsider kao razlog ovog pada navodi promjene u gospodarstvu Kine. Krajem prošlog i početkom ovog stoljeća Kina je uvozila velike količine sirovina i goriva, a njezino gospodarstvo raslo je na temelju jeftine radne snage. Međutim u godinama od 2010. nadalje kinesko gospodarstvo smanjuje uvoz, a istovremeno dolazi i zasićenja svjetske flote brodovima za masovni prijevoz. Procjena je da trenutno postoji više od 50.000 brodova za prekoceanski prijevoz robe i sirovina. Većina tih brodova kupljeni su na temelju kredita i zaduženja koje zbog pada vozarina njihovi vlasnici nisu sposobni vratiti. Ovdje nastaje pojam „zombi brodova“ – brodova koji ne donose nikakvu vrijednost, jer zapravo

sva zarada koju oni donesu poduzeću odlazi na pokrivanje troškova nabave tih brodova, a njihova prodaja se ne isplati jer zbog zasićenosti tržišta prijevoza brodovima pada vrijednosti.

Sljedeći graf prikazuje početak oporavka Baltic Dry Index-a nakon 2016. godine. Ovo je izrazito važno za primjer Atlantske plovidbe jer predviđa poboljšanje profitabilnosti poslovanja. Važna napomena je kako bi vjerojatno najtočniji rezultat simulacija poslovanja Atlantske plovidbe bila upravo onda kada bi se poslovni prihodi ili drugi aspekti poslovanja mogli povezati sa Baltic Dry Indexom. Međutim cilj ovog rada bio je projicirati rezultate poslovanja Atlantske plovidbe iz jednog drugog gledišta. Pretpostavljam da će razlika rezultata dobivenih u modelu i stvarnih poslovnih rezultata ovisiti ponajviše o promjenama Baltic Dry Index-a, odnosno da će uz stabilni Baltic Dry Index simulirani rezultati biti blizu stvarnima.



Slika 2: Graf koji prikazuje promjene vrijednosti Baltic Dry Index-a (preuzeto s: <https://tradingeconomics.com/commodity/baltic>, dostupno 11.7.2018.)

2. Metode i tehnike rada

Za izradu ovog rada koristio sam alat MS Office-a Excel. Excel je sveprisutan i njegova upotreba kod izrade financijskih izvještaja u praksi je standard. Prema Render, B. (2000.) modeliranje se provodi sljedećim koracima:

1. Definiranje problema:

Problem koji nas zanima u ovom slučaju je financijski rezultat (točnije slobodni novčani tijekovi) u sljedećim godinama za poduzeće koje promatramo.

2. Razvijanje modela:

Model je sastavljen u Excelu, detaljnije objašnjenje slijedi u nastavku poglavlja

3. Prikupljanje ulaznih podataka:

Ulazne podatke za model preuzeo sam sa web stranica Zagrebačke burze i web stranice AnicaZna. Ulazni podaci za model su financijska izvješća za prethodne godine, te bilješke koje dolaze uz njih.

4. Razvijanje rješenja:

Ulazne podatke analizirao sam tako da sam izračunao postotne promjene stavaka financijskih izvještaja iz kvartala u kvartal. Na temelju tih postotnih promjena kasnije dobiveni prosjek i standardna devijacija poslužiti će za simuliranje sljedećih godina.

5. Testiranje rješenja:

Kada je model završen rezultati su izgledali nerealno. Više puta sam prolazio kroz model i provjeravao kako koje varijable utječu na krajnji rezultat. Usklađivao sam utjecaje više varijabli kako bi rezultati bili realni i što precizniji.

6. Analiza rezultata:

Kada je model počeo davati rezultate koji su imali smisla i njih je trebalo staviti u kontekst. Model predviđa nastavak poboljšanja poslovanja i rast prihoda.

7. Implementacija rezultata:

Kada bi model bio u potpunosti detaljan i kada bi svi podaci o proteklim godinama bili dostupni, rezultati simulacije mogli bi se koristiti za predviđanje cijena dionica te odluku o eventualnom investiranju.

Na početku sam u Excelu sastavio po jedan list za svaki financijski izvještaj koji ulazi u model i na njima sam u tablici prikazao stavke izvještaja koje su potrebne za kasniju simulaciju i koje prikazuju najbitnije dijelove izvještaja. Listovi su organizirani tako da svaki sadrži podatke za svaku promatranu godinu, po kvartalima. Promatrane godine su od 2013. do 2017.

Nakon unosa podataka za svaki kvartal u tablice bilo je potrebno analizirati kretanje tih podataka iz godine u godinu. Kod Izvještaja o novčanim tokovima promatrao sam prvo koliki je porast (ili pad) postotni za svaku stavku na godišnjoj razini, a onda koliki je udio svakog kvartala u godišnjem iznosu. Postotak porasta izračunao sam sljedećom formulom:

$$\text{Postotak promjene} = \frac{\text{Nova vrijednost} - \text{Stara vrijednost}}{\text{Stara vrijednost}}$$

Udio nekog kvartala u godišnjoj vrijednosti:

$$\text{Udio} = \frac{\frac{\text{Vrijednost kumulativa kvartala}}{\text{Godišnji prosjek}}}{\text{Broj tromjesječja na koje se odnosi izvještaj}}$$

Broj tromjesječja na koje se odnosi kvartalni izvještaj je za prvi kvartalni izvještaj 1, jer se on odnosi na razdoblje od 1.1. do 1.3. u toj godini; za drugi kvartalni izvještaj 2 jer se on odnosi na ukupno 6 mjeseci (1.1. do 1.6.), a za treći kvartalni izvještaj 3.

Kod bilanci sam promatrao promjene iz kvartala u kvartal (formula ista kao i za postotak promjene kod novčanih tokova), jer je bilanca stanje na dan, zbog čega kod nje ne postoji vremenska komponenta. Na kraju kod računa dobiti i gubitka promatrao sam promjene posebno za svaki kvartal: prvi u odnosu na prvi prethodne godine, drugi u odnosu na drugi itd.

Kod svih izvještaja četvrti kvartali najbolje opisuju stanje tvrtke i njihovom usporedbom se najbolje vidi u kojem smjeru se kreću vrijednosti.

Kada sam na objašnjeni način izračunao postotne promjene za stavke financijskih izvještaja projicirao sam ih na sljedećih 5 godina uz pretpostavku da će se svake godine svaka stavka onoliko postotno povećavati/smanjivati koliko se u prosjeku smanjivala u proteklim godinama. Ovakav pristup bio je očigledno pogrešan, jer su neke vrijednosti izrazito rasle i poslovni rezultat nakon nekoliko godina projekcije iznosio je više milijardi, pri čemu je i raspored vrijednosti bio nelogičan. Međutim ovakve projekcije dobro su mi poslužile jer sam lakše shvatio koliki utjecaj na poslovni rezultat imaju koje varijable.

Nakon projiciranja uz korištenje prosjeka izradio sam projekciju temeljenu na simulaciji. Simulaciju sam napravio Monte Carlo metodom. Prema Render, B. (2000.) Monte Carlo metoda simulacije može se primijeniti kada simulirani sustav sadrži elemente čije ponašanje se može opisati vjerojatnostima. Kao primjere takvih elemenata autor navodi sljedeće varijable:

- Potražnja za proizvodom na dnevnoj ili tjednoj razini
- Vrijeme isporuke narudžbi
- Vrijeme između kvarova stroja
- Vrijeme između pristizanja jedinica za pružanje usluga

- Trajanje pružanja usluge
- Trajanje aktivnosti u projektu
- Broj radnika odsutnih na poslu

Render, B. (2000.) navodi kako se vjerojatnosti kojima se opisuju varijable u sustavu dobivaju na temelju prošlih vrijednosti. Autor kao korake za provedbu Monte Carlo simulacije navodi:

1. Određivanje vjerojatnosti distribucije važnih ulaznih varijabli
2. Izrada kumulativa vjerojatnosti distribucije za svaku određenu varijablu
3. Određivanje intervala slučajnih brojeva za svaku varijablu
4. Generiranje slučajnih brojeva
5. Simulacija niza rješenja

Međutim u ovom primjeru simulaciju sam provodio drugačijim koracima. Razlog tomu je što Excel ima ugrađenu formulu kojom je moguće generirati slučajne brojeve na temelju standardne devijacije i prosjeka. Ta standardna devijacija i prosjek mogu se odnositi na očekivane ili željene vrijednosti, ali također mogu biti i izračunati prema prošlim vrijednostima. Korištenjem ovog pristupa pojednostavio sam generiranje slučajnih brojeva, što u modelu znači preglednost, uštedu vremena izrade i realizacije. Za simulacije se koristi pretpostavka o normalnoj distribuciji slučajnih varijabli.

Za svaku stavku financijskih izvještaja simulirao sam postotne promjene: po 100 puta za kvartal – te uzeo prosjek brojeva dobivenih simulacijom. Dobiveni brojevi su postotne promjene tih varijabli koji će računati novu vrijednost (u simuliranim godinama) u odnosu na vrijednosti u prethodnim godinama. Te brojeve generirao sam sljedećom excelovom formulom:

`=NORM.INV(RAND();'RDG 2013-2017'!W20;'RDG 2013-2017'!X20)`

Argumenti formule su: slučajni broj, prosjek prošlih vrijednosti i standardna devijacija prošlih vrijednosti. A rezultat formule je slučajni broj u normalnoj distribuciji, što znači da se kod većeg broja korištenja ove formule češće dobivaju brojevi bliži srednjoj vrijednosti, a ekstremi rjeđe – kao na Gaussovoj krivulji.

Projekcija temeljena na simulaciji pokazala je puno „prirodniji“ rezultat u odnosu na projekciju temeljenu na prosjeku. S obzirom da se simulira promjena za svaki kvartal vrijednosti stavaka izvještaja u nekim kvartalima rastu, a u nekima padaju, ovisno o simuliranom broju, zbog čega vrijednost stavke ne raste ili pada konstantno. Iako ukupno gledano sve vrijednosti nakon 5 simuliranih budu promijenjene, ta promjena je realna.

3. Model i projekcija poslovanja Atlantske plovidbe

U ovom poglavlju opisati ću i prikazati simulacijski model koji sam izradio u MS Excelu. Cilj izrade modela bio je pokazati kako određene simulirane vrijednosti utječu na financijske pokazatelje poduzeća. Pretpostavke modela su vrijednosti za godine prije simulacije. Provedbom simulacije model automatski generira financijske izvještaje i slobodni novčani tok i cijenu dionice. Kasnije u tekstu prikazani su i rezultati simulacije, te njihovo tumačenje.

3.1. Sadržaj modela

Model u Excelu podijeljen je na listove. Svaki list je cjelina koja sadrži tablice vezane za neki financijski izvještaj s podacima za prethodna razdoblja i/ili analizom tih podataka. Po listovima sadržaj je sljedeći:

Naziv lista	Sadržaj
N.T. 2013-1Q 2018	List sadrži tablicu sa izvještajima o novčanom tijeku sastavljenima indirektnom metodom za vremensko razdoblje od 1. kvartala 2013. godine do 1. kvartala 2018 godine. U tablici su uneseni podaci za sve kvartale u tom razdoblju, te je izračunati kvartalni prosjek za svaku stavku izvještaja, porast tog prosjeka na godišnjoj razini, te odstupanje u svakom kvartalu u odnosu na taj prosjek. Ispod tablice sa izvještajima dodatno su izračunate godišnje promjene za amortizaciju, te promjene za smanjenje i povećanje novčanih tokova od poslovnih aktivnosti kao odnos određenih kvartala unutar godina: 1. kvartal u odnosu na 1. prethodne godine, 2. u odnosu na 2. itd.

Naziv lista	Sadržaj
Bilance 2013-2017	<p>Ovaj list sadrži tablicu koja prikazuje sažeti oblik bilanci za sve kvartale u godinama od 2013. do 2017. Nisu prikazane sve stavke bilanci, već samo one koje će biti potrebne za kasnije simuliranje novčanog tijeka: potraživanja, zalihe, kratkoročne obveze; te one koje upotpunjuju sliku o stanju u poduzeću: nematerijalna i materijalna dugotrajna imovina, ukupni iznos kratkotrajne imovine, kapital i rezerve, zadržana dobit, dobit poslovne godine, dugoročne i kratkoročne obveze.</p> <p>Kod ovih podataka također su izračunate postotne promjene iz kvartala u kvartal koje govore koliko iznos koje od navedenih stavaka postotno raste ili pada u kojem razdoblju. Za dobivene postotne promjene izračunati je prosjek i standardna devijacija (po stavkama). To će kasnije poslužiti kod simulacije.</p>
RDG 2013-2017	<p>Ovaj list sadrži dvije tablice koje se odnose na Račune dobiti i gubitka od godine 2013. do godine 2017. U prvoj tablici su upisani podaci iz tih godina po stavkama. A u drugoj su izračunate postotne promjene. Kod računa dobiti i gubitka promjene sam računao prema kvartalima, dakle 1. kvartal u odnosu na 1. kvartal prethodne godine, 2. u odnosu na 2., 3. u odnosu na 3. i godišnje iznose u odnosu na godišnje iznose prethodne godine. Ovdje je također izračunati udio poslovnih rashoda u poslovnim prihodima. Za sve stavke s izračunatim postotnim promjenama također su izračunati i prosjek i standardna devijacija.</p>

Naziv lista	Sadržaj
Nt Predviđanje prosjekom 1. dio	<p>Ovaj list sadrži tablicu s postotnim promjenama po stavkama novčanih tijekova po godinama od 2014. do 2017. izračunatim prema prethodnim vrijednostima, te od 2018. do 2022. gdje su postotne promjene nastale kao prosjek prethodnih godina. Tako je npr. u 2018. godini Ukupno povećanje novčanog tijeka od poslovnih aktivnosti 54,48%, jer je to prosjek od prethodnih 4 godine. U 2019 to je 64,85% itd...</p> <p>Druga tablica na ovom listu prikazuje udjele svakog kvartala u ukupnom iznosu godine – po godinama od 2013. do 2017., te kasnije od 2018. do 2022 gdje je udio svakog kvartala po stavkama izračunat kao prosječni udio iz prethodnih godina.</p>
Nt Predviđanje prosjekom 2. dio	<p>Na ovom listu nalazi se izvještaj o novčanim tijekovima za godine 2017. do 2022. Podaci za godinu 2017. su stvarni, a za godine 2018. do 2022. su izračunati tako da je prethodna godina pomnožena sa postotnom promjenom izračunatom na prethodnom listu za pripadajuću godinu.</p>
Nt Predviđanje prosjekom 3. dio	<p>Na ovom listu nalazi se izvještaj o novčanim tijekovima za godine 2017. do 2022. Podaci za godinu 2017. su stvarni, a za godine 2018. do 2022. su izračunati tako da je prethodna godina pomnožena sa postotnom promjenom izračunatom na prethodnom listu, međutim svaki puta za prosjek izračunat za godine od 2017. do 2022. Budući da je svako novo računanje (u odnosu na prethodne godine) dodatno povećavalo rezultat, on je nakon nekoliko godina narastao izrazito nerealno.</p> <p>Ni jedan od ovih novčanih tokova dobivenih na temelju prosjeka ne izgleda pretjerano realno, jer se sve promjene kroz godine događaju linearno. Međutim sastavljene tablice i dobiveni rezultati dobro su poslužili kasnije kod sastavljanja simulacije.</p>

Naziv lista	Sadržaj
Nt Simulacijski model –godišnje	Na ovom listu nalazi se tablica u kojoj je na temelju postotnih promjena vrijednosti u godinama od 2013. do 2017. izračunati minimumi, maksimumi, prosjek i standardna devijacija. Nakon toga je simulirano 100 brojeva za svaku stavku i dobivene su simulirane postotne promjene po stavkama.
Nt simulacija za odstupanja kv.	Na ovom listu nalaze se simulacije od po 100 brojeva za kvartale po svakoj stavci Izvještaja o novčanim tijekovima. Iz tih 100 brojeva izračunati su prosjek, minimum, maksimum i standardna devijacija, te su u grafikonima prikazani njihovi rasporedi. Ovo je napravljeno da bi se vidjelo kako je većina tih simuliranih vrijednosti blizu prosječnoj vrijednosti što je i očekivano zbog korištenja formule „norminv“.
Nt simulacija po kvartalima	<p>Na ovom listu se nalazi izvještaj o novčanim tijekovima sastavljen tako da su brojevi simulirani u prethodnim listovima za postotne promjene po godinama pomnoženi s iznosima proteklih godina, a tako dobivene godišnje vrijednosti poslužile su da se izračunaju vrijednosti kvartala – koristeći simulirane brojeve za kvartale iz prošlog lista.</p> <p>Međutim ovakav pristup ne pokazuje gotovo ništa osim „suhih“ brojeva, te ne opisuje pretjerano dobro promjene u poduzeću. Zbog toga sam odlučio simulirati odjednom i bilancu, račun dobiti i gubitka i izvještaj o novčanim tijekovima i odnose između njih. Smatram da se prikazom svih triju izvještaja bolje vidi kakvo je zapravo stanje u poduzeću.</p>

Naziv lista	Sadržaj
Simulacija izvještaja priprema	<p>Ovaj list sastoji se od triju financijskih izvještaja: bilance, računa dobiti i gubitka i izvještaja o novčanim tijekovima. Kako bi simulirao poslovanje u godinama od 2018. do 2022. prikazati ću ova tri izvještaja. Neke od stavaka kod nekih od ovih izvještaja mogu se izvesti iz stavaka drugih izvještaja. Npr. ako simuliram potraživanja i zalihe u bilanci, mogu u izvještaju o novčanim tijekovima izračunati smanjenje zaliha, povećanje zaliha, smanjenje potraživanja i povećanje potraživanja. Vođen tim razmišljanje tablicu u ovom listu popunio sam sa simuliranim postotcima – za stavke koje je potrebno simulirati. Stavke koje ću dobiti računski ostavio sam prazne. Ovaj list služi kao podloga za završni prikaz izvještaja na kojemu su predloženi brojevi.</p> <p>Simulacija je ovdje provedena tako da se za svaku stavku u svakom kvartalu u simuliranim godinama generira 100 slučajnih brojeva, te se računa njihov prosjek. Taj prosjek će se u sljedećem listu množiti sa prethodno dostupnim vrijednostima kako bi se dobile nove vrijednosti.</p>

Naziv lista	Sadržaj
Simulacija izvještaja prikaz	<p>Struktura ovog lista jednaka je kao i struktura prethodnog, međutim na ovom listu nisu postotci već vrijednosti (u tis. kn). Označene plavom bojom su stavke izvještaja koje su dobivene simulacijom – generiranjem slučajnih brojeva. Ostale (neoznačene) stavke računaju se iz simuliranih stavaka ili se prenose iz prošlih razdoblja. Ono što je fokus cijelog modela ovdje se nalazi na dnu tablice: Novac i novčani ekvivalenti na kraju razdoblja. Proučavajući financijske izvještaje za prethodne godine ustanovio sam da mogu očekivati rast novca i novčanih ekvivalenata u godinama koje slijede. Rezultati simulacije to potvrđuju. Na simulaciju sam također dodao i diskontiranje novčanog toka što je uobičajena praksa kod predviđanja i izračuna vrijednosti za budućnost.</p> <p>Na dnu lista računa se cijena dionice/novac po dionici koji ostaje na kraju 2022. U toj formuli koristi se diskontirani novčani tok za 2022. i broj dionica koji je trenutno u opticaju: 1.395.000.</p>
Simulacija za cijenu dionica	<p>Na ovom listu sam primjenom Excelove What-If analize ponovio simulaciju iz prošlog lista još 200 puta te uzeo prosjek. Ovdje su prikazani rezultati simulacije za diskontirani novčani tijek na kraju 2022. te cijene dionica.</p> <p>Bilo bi idealno ponoviti istu simulaciju više od 200 puta, međutim čak i na jakoj računalnoj konfiguraciji Excel počinje zastajkivati u radu. To otežava pregledavanje dokumenta i izmjene. Ponavljanje od 200 puta dovoljno je dobro za primjer koji pokazuje kako izraditi simulaciju.</p>

Tablica 1: Sadržaji listova koji čine excel datoteku modela

3.2. Pretpostavke i ulazni podaci modela

Glavna stavka na kraju modela je diskontirani novčani tijek, odnosno cijena dionice. Diskontirani novčani tijek računa se tako da se slobodni novčani tijek na kraju razdoblja diskontira prema određenoj diskontnoj stopi. Slobodni novčani tijek dobivamo tako da u Izvještaju o novčanim tokovima novcu i novčanim ekvivalentima s početka razdoblja dodamo ukupno povećanje novčanog tijeka ili oduzmemo ukupno smanjenje. Iz toga zaključujemo da za prikaz diskontiranog novčanog tijeka očigledno trebamo izvještaj o novčanim tokovima. U prvoj verziji ovog modela poslovnog sustava izradio sam analizu i simulaciju samo izvještaja o novčanim tokovima. Međutim ovaj izvještaj ne otkriva previše, te je puno bolje promatrati ga u kombinaciji sa ostalim poslovnim izvještajima. Stavke kao što su dobit prije poreza ili smanjenje kratkoročnih obveza u izvještaju o novčanim tokovima možemo pronaći u bilanci i RDG-u. A ako simuliramo i bilancu i RDG onda vidimo što sve utječe na takve stavke. Tako dobivamo širu sliku o financijama poduzeća i možemo lakše zaključiti što točno utječe na poslovni rezultat na kraju godine.

Izrada modela započinje unosom prethodnih financijskih izvještaja u Excel. Kod izvještaja o novčanim tokovima (indirektna metoda) koristio sam sve stavke izvještaja. Izvještaje sam preuzeo sam stranica Zagrebačke burze. Najbitnije stavke izvještaja o novčanim tokovima za ovaj model su povećanja i smanjenja novčanog tijeka od financijskih i investicijskih aktivnosti, jer njih model simulira direktno na temelju prošlih vrijednosti. Povećanje i smanjenje od poslovnih aktivnosti ne simuliraju se na temelju prošlih vrijednosti iz izvještaja o novčanim tokovima, nego se računaju prema simuliranim vrijednostima u bilanci i računu dobiti i gubitka.

3.3. Analiza postotnih promjena

Prije pokazanim metodama izračunao sam postotne promjene za svaku stavku financijskih izvještaja. Analiza tih promjena obuhvaća proučavanje kretanja vrijednosti stavaka i proučavanje skokova koji se događaju u nekim kvartalima. S obzirom da financijska izvješća na stranicama burze prate i opisi događanja u poduzeću većina velikih promjena nekih stavaka iz kvartala u kvartal da se povezati s nekim događajem, npr. prodaja ili kupovina dugotrajne materijalne imovine, uzimanje kredita, isplata dividendi i dr.

U ovom poglavlju izdvojiti ću primjere u kojima se vide postotne promjene koje odudaraju od prosjeka za određene stavke. Prepoznavanje ovakvih promjena jedan je od najvažnijih dijelova postavljanja ovog modela jer će se zapravo te promjene ignorirati te će se tako smanjiti njihov utjecaj na krajnji rezultat. Svako takvo odstupanje ima svoj uzrok te kod projekcije za sljedeće godine računamo da se neki „iznimni“ događaji neće događati jer je njih teško predvidjeti, a tako i promjene koje oni donose. Prema podacima dostupnima sa stranica burze (bilješke uz izvještaje) pokušati ću objasniti razloge velikih povećanja ili smanjenja kod stavaka gdje takve promjene budu prisutne.

Kod nekih priloženih isječaka iz tablica moguće je primijetiti izrazito velike postotne promjene koje nisu označene kao „veliki skok“, a očito odudaraju od prosjeka za tu stavku. To su promjene u stavkama koje se ne simuliraju u modelu, već se u projekciji njihov iznos računa iz drugih stavaka. Zbog toga nije potrebno kod njih neutralizirati utjecaj velikih postotnih promjena, jer one kasnije ne služe za daljnja simuliranja.

Porast prosjeka po godinama		2014	2015	2016	2017	2018
I. Ukupno povećanje novčanog tijeka od poslovnih aktivnosti (001 do 007)	007	12,99%	-110,88%	243,95%	71,85%	54,48%
II. Ukupno smanjenje novčanog tijeka od poslovnih aktivnosti (008 do 012)	012	-25,18%	-93,68%	696,71%	346,70%	231,14%
A1) NETO POVEĆANJE NOVČANOG TIJEKA OD POSLOVNIH AKTIVNOSTI (007-012)	013	30,20%	-100,00%	143,51%	76,49%	37,55%
A2) NETO SMANJENJE NOVČANOG TIJEKA OD POSLOVNIH AKTIVNOSTI (012-007)	014	0,00%	115,34%	-100,00%	0,00%	3,83%
III. Ukupno novčani primici od investicijskih aktivnosti (015 do 019)	020	84,96%	131,88%	-67,23%	-98,42%	12,80%
IV. Ukupno novčani izdaci od investicijskih aktivnosti (021 do 023)	024	-53,00%	93,86%	-17,50%	-57,30%	-8,49%
B1) NETO POVEĆANJE NOVČANOG TIJEKA OD INVESTICIJSKIH AKTIVNOSTI (020-024)	025	241,81%	161,72%	-96,14%	-100,00%	51,85%
B2) NETO SMANJENJE NOVČANOG TIJEKA OD INVESTICIJSKIH AKTIVNOSTI (024-020)	026	0,00%	0,00%	0,00%	608,81%	152,20%
V. Ukupno novčani primici od financijskih aktivnosti (027 do 029)	030	-305,87%	151,50%	-3,62%	-100,00%	-64,50%
VI. Ukupno novčani izdaci od financijskih aktivnosti (031 do 035)	036	-3,87%	51,19%	-51,63%	-93,59%	-24,48%
C1) NETO POVEĆANJE NOVČANOG TIJEKA OD FINACIJSKIH AKTIVNOSTI (030-036)	037	0,00%	0,00%	0,00%	0,00%	0,00%
C2) NETO SMANJENJE NOVČANOG TIJEKA OD FINACIJSKIH AKTIVNOSTI (036-030)	038	80,34%	-0,31%	-76,43%	-80,05%	-19,11%

Slika 3: Porast prosjeka po godinama u Izvještajima o novčanim tijekovima (vlastita izrada – isječak iz modela u Excelu)

Tablica prikazuje godišnje promjene vrijednosti u izvještaju o novčanim tijekovima. Od 2014. do 2017. to su postotci dobiveni analizom, a 2018. godina prikazuje prosjek proteklih godina. Prvo što primjećujemo je postotno povećanje od skoro 700% 2016. godine u stavci

„Ukupno smanjenje novčanog tijeka od poslovnih aktivnosti“. Proučavajući „Revidirani izvještaj posloводства za razdoblje I-XII 2016. godine“ Grupe Atlantska plovdba Dubrovnik preuzeti sa stranica Zagrebačke burze otkrivamo kako je smanjenje novčanog tijeka uzrokovano izrazito niskim vozarinama na svjetskom tržištu prijevoza suhih tereta. U izvješću se također navodi kako je ostvareni gubitak bio očekivani, vjerojatno zbog predviđanja pada vozarina.

Drugi primjer velikog odstupanja od prosječnih postotnih promjena vidljivih u ovoj tablici je neto smanjenje novčanog tijeka od investicijskih aktivnosti u 2017. godini. U „Revidiranom izvještaju o poslovanju za razdoblje I-XII 2017. godine“ navodi se odljev od 47.641.226kn za „Ostale novčane izdatke od investicijskih aktivnosti“, što znači da navedeno odstupanje nije prouzročilo ni kupovanje dugotrajne materijalne imovine niti stjecanje vlasničkih ili dužničkih financijskih instrumenata. Iz dokumenta nije vidljivo što točno je uzrokovalo ovakav porast smanjenja novčanog tijeka od investicijskih aktivnosti.

Sljedeća slika prikazuje dio tablice sa postotnim promjenama po kvartalima u bilanci za 2015. godinu. U 2. kvartalu 2015. godine pod kategorijom potraživanja zabilježen je skok od 181%. Kako bi se utjecaj takvih velikih odstupanja od prosjeka smanjio njihove vrijednosti su izbrisane te ih Excel ne koristi u daljnjem radu. Zbog toga su kasnije prosjek i standardna devijacija bliže 0% te simulacija ne odlazi u ekstreme. Ovo je u priloženom Excelu jasno vidljivo. S „veliki skok“ označena su sva polja tablice čije su vrijednosti izbrisane kako bi se izbjegao njihov utjecaj na simulaciju.

2015							
1	Porast	2	Porast	3	Porast	4	Porast
2.367.194.199,00	12%	2.154.717.735,00	-9%	2.137.842.181,00	-1%	1.967.109.914,00	-8%
2.227.913.680,00	16%	1.879.646.540,00	-16%	1.935.875.462,00	3%	1.795.746.358,00	-7%
12.487.007,00	0%	12.458.290,00	0%	12.443.760,00	0%	12.429.230,00	0%
1.963.471.480,00	16%	1.751.664.069,00	-11%	1.901.945.380,00	9%	1.758.073.131,00	-8%
138.622.887,00	-29%	204.209.984,00	47%	201.762.591,00	-1%	170.719.018,00	-15%
9.166.079,00	-54%	25.799.438,00	veliki skok	24.250.859,00	-6%	19.978.492,00	-18%
60.561.113,00	3%	51.594.190,00	-15%	44.763.138,00	-13%	46.290.436,00	3%
2.367.194.199,00	12%	2.154.717.735,00	-9%	2.137.842.181,00	-1%	1.967.109.914,00	-8%
852.156.037,00	-3%	796.910.578,00	-6%	766.057.675,00	-4%	659.654.606,00	-14%
175.059.633,00	-82%	162.265.054,00	-7%	173.677.593,00	7%	146.238.931,00	-16%
-45.763.798,00	94%	-74.892.830,00	-64%	-101.172.114,00	-35%	-232.150.112,00	-129%
1.234.923.443,00	20%	1.152.967.563,00	-7%	1.207.029.236,00	5%	1.000.287.288,00	-17%
189.675.486,00	-2%	122.237.345,00	-36%	89.926.089,00	-26%	234.302.083,00	161%

Slika 4: Balance iz godine 2015 po kvartalima (vlastita izrada – isječak iz modela u Excelu)

Odakle skok u kratkotrajnim potraživanjima u 2015. godini bitno je otkriti kako bi se dokazalo da je on zapravo anomalija, a ne uobičajena promjena u poslovanju – jer bi tada morao biti u tablici te omogućiti da se i u simulaciji događa nešto slično. U „Nerevidiranom konsolidiranom financijskom izvještaju za razdoblje I-VI 2015. godine“ pod bilješkama je navedeno kako je u travnju 2015. godine Arbitražno vijeće dovršilo dva arbitražna postupka,

te su na temelju zaprimljenih presuda Atlantskoj plovidbi d.d. priznata potraživanja za dva broda. Od toga je 30. lipnja naplaćeno potraživanje za prvi brod, a naplata potraživanja za drugi brod obavljena je nakon njegove isporuke. Zbog ove presude Arbitražnog vijeća povećala su se potraživanja u 2. kvartalu 2015. godine.

2017							
1	Porast	2	Porast	3	Porast	4	Porast
1.775.164.017,00	-4%	1.536.126.743,00	-13%	1.413.727.420,00	-8%	1.420.231.989,00	0%
1.662.412.013,00	-4%	1.423.256.696,00	-14%	1.261.651.552,00	-11%	1.288.701.453,00	2%
12.247.155,00	-1%	12.348.460,00	1%	12.328.503,00	0%	12.636.163,00	2%
1.616.809.527,00	-4%	1.381.575.457,00	-15%	1.220.851.185,00	-12%	1.272.587.665,00	4%
112.752.004,00	-10%	112.870.047,00	0%	133.499.042,00	18%	117.848.578,00	-12%
5.084.885,00	-79%	17.429.427,00	veliki skok	25.767.700,00	48%	49.871.549,00	94%
38.705.888,00	23%	33.765.810,00	-13%	29.291.715,00	-13%	21.298.060,00	-27%
1.775.164.017,00	-4%	1.536.126.743,00	-13%	1.413.727.420,00	-8%	1.420.231.989,00	0%
573.501.390,00	-2%	556.750.267,00	-3%	545.994.183,00	-2%	557.885.979,00	2%
-77.539.797,00	5258%	-68.114.636,00	12%	-65.186.185,00	4%	-72.692.111,00	-12%
2.837.288,00	103%	40.738.018,00	1336%	42.520.468,00	4%	81.323.344,00	91%
877.142.937,00	-3%	797.118.032,00	-9%	759.842.542,00	-5%	418.814.809,00	-45%
302.791.274,00	-9%	180.941.086,00	-40%	96.084.837,00	-47%	412.322.815,00	329%

Slika 5: Balance iz godine 2017, s postotnim promjenama po kvartalima (vlastita izrada – isječak iz modela u Excelu)

Slika 5 prikazuje dio iste tablice koji se odnosi na 2017. godinu. I ovdje je u 2. kvartalu vidljivo polje označeno s „veliki skok“, taj se red tablice odnosi na kratkotrajna potraživanja, a vrijednost koju je ta oznaka zamijenila je 243%. Međutim ako pogledamo i prethodnu godinu vidimo da je ovaj skok zapravo uzrokovan padom potraživanja u prvom kvartalu, što je ovdje ponovno dignuto blizu uobičajenih vrijednosti. U bilješkama uz financijske izvještaje ne postoji nikakvo obrazloženje ni za jedan ni drugi kvartal te promjene koje su ovdje nastale, a jedino je vidljivo da se navedeni brojevi odnose na potraživanja od kupaca, pa je moguće zaključiti da je vjerojatno ostvareno manje prometa u prvom kvartalu nego što je bilo uobičajeno. Također možemo uzeti u obzir Dry Baltic Index – index prema kojem se računaju cijene brodarina, te vidimo da je upravo u prvom kvartalu 2017. on imao izrazito niske vrijednosti.

Slika 6 prikazuje isječak iz tablice s postotnim promjenama za račun dobiti i gubitka u godini 2014. u odnosu na 2013. godinu. Oznakom „veliki skok“ označeno je više polja. To znači da su ove vrijednosti utjecale na prosjek i standardnu devijaciju previše da bi oni u simulaciji davali brojeve u realnom rasponu. Iako u bilješkama koje prate financijske izvještaje ne postoji objašnjenje za točno određene stavke možemo pretpostaviti da su velika povećanja u 2014. godini izazvana dizanjem vozarina u 2014. nakon ekstremno niskih vozarina u 2013. godini. Prema revidiranom izvještaju posloводства za razdoblje I-XII 2014. godine zbog značajnog smanjenja vrijednosti brodova u 2014. godini bilo je potrebno obaviti vrijednosno usklađivanje brodova. U kategoriji „Poslovni rashodi“ zbog toga se pojavio veliki skok u 4. kvartalu.

Postotne promjene	2014			
	1	2	3	4
Poslovni prihodi	-12%	veliki skok	-15%	4%
Prihodi od prodaje	-18%	-9%	27%	4%
Ostali poslovni prihodi	veliki skok	veliki skok	-93%	6%
Poslovni rashodi	-1%	19%	-1%	veliki skok
Financijski prihodi	-87%	-47%	veliki skok	veliki skok
Financijski rashodi	-37%	-19%	54%	13%
Ukupni prihodi	-14%	83%	-14%	7%
Ukupni rashodi	-5%	16%	3%	142%
Dobitak ili gubitak prije oporezivanja	90%	-381%	-86%	11580%
Porez na dobit	0%	0%	0%	0%
Dobit ili gubitak razdoblja	90%	-331%	-86%	11580%

Slika 6: Račun dobiti i gubitka iz godine 2014: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)

Slika 7 prikazuje isječak iz iste tablice za godinu 2015. U prva tri kvartala događaju se veliki skokovi pod stavkama Financijski prihodi i Financijski rashodi. U oba slučaja promjena je povećanje. Iz bilješki priloženih financijskim izvještajima i samih financijskih izvještaja vidljivo je da promjene nastaju zbog velikih tečajnih razlika. One su izazvale povećanja i financijskih prihoda i rashoda u odnosu na prethodna razdoblja. Također je vidljivo da su na kraju godine te promjene većinom neutralizirane, to jest da je utjecaj velikih tečajnih razlika smanjen.

2015			
1	2	3	4
-45%	-23%	61%	-36%
-49%	47%	54%	-29%
16%	-89%		-73%
-33%	38%	121%	-59%
veliki skok	veliki skok	veliki skok	-35%
veliki skok	veliki skok	veliki skok	32%
-38%	-20%	65%	-36%
-11%	56%	132%	-56%
108%	-239%	-1975%	-71%
0%	0%	0%	0%
108%	-270%	-2387%	-71%

Slika 7: Račun dobiti i gubitka iz godine 2015: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)

Slika 8 prikazuje promjene u istoj tablici za sljedeću godinu: 2016. Ovdje su kao veliko povećanje označena polja pod stavkama financijskih prihoda u prva tri kvartala godine. Kao i u prethodnoj godini i ovdje se porast objašnjava tečajnim razlikama.

2016			
1	2	3	4
57%	14%	-11%	-3%
60%	10%	-15%	-6%
32%	61%	39%	43%
43%	17%	-7%	-20%
veliki skok	veliki skok	veliki skok	287%
-45%	-32%	-29%	-5%
147%	46%	10%	8%
17%	9%	-10%	-18%
-157%	-72%	-65%	-62%
0%	0%	0%	0%
-146%	-72%	-65%	-62%

Slika 8: Račun dobiti i gubitka iz godine 2016: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)

U godini 2017. više se ne pojavljuju takvi izraziti skokovi kod financijskih prihoda i rashoda. Jedina anomalija javlja se u godišnjem izvještaju pod stavkama poslovnih prihoda i ostali poslovni prihodi, kod čega drugo izaziva prvo. Porast koji se ovdje događa nije moguće točno odrediti samo iz bilješki i poslovnih izvještaja. U 2016. godini ostali poslovni prihodi iznosili su samo otprilike 35 milijuna kuna, što je bilo niže nego svake godine prije, dok su se u 2017. digli na 155 milijuna, što ne bi predstavljalo izrazito veliki skok u odnosu na neku godinu prije 2016.

2017			
1	2	3	4
19%	21%	29%	veliki skok
25%	15%	23%	20%
-34%	64%	76%	veliki skok
-19%	-24%	-12%	4%
-94%	-35%	-25%	8%
-19%	40%	24%	8%
-31%	6%	17%	47%
-19%	-17%	-7%	5%
-89%	-296%	-219%	-201%
0%	0%	0%	0%
-89%	-260%	-198%	-183%

Slika 9: Račun dobiti i gubitka iz godine 2017: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)

3.4. Postavke simulacije

Poglavlje će prikazati financijske izvještaje simulirane u modelu. Opisati će ulazne vrijednosti koje dolaze iz prethodnih tablica u tablicu koja služi kao temelj simulaciji. Slike 10 i 11 prikazuju isječke iz tablice u kojoj se generiraju slučajni brojevi. Svaka od plavo označenih stavaka u dijelovima tablice koji se odnose na bilancu, RDG i izvještaj o novčanim tijekovima simulira se u krajnjem modelu. Ostale, neoznačene stavke u modelu se računaju na temelju generiranih stavaka. Za svaku od označenih stavaka slučajni se brojevi generiraju po 100 puta za svaki projicirani kvartal, njih ukupno 20 što ukupno čini 5 godina. Slučajni brojevi generiraju se Excelovom formulom =norm.inv() već opisanom u jednom od prethodnih poglavlja. Od 100 slučajnih brojeva generiranih za svaki kvartal računa se prosjek. Taj prosjek u sljedećem listu Excela koristi se za računanje same vrijednosti u određenom kvartalu.

Osim plavom bojom označenih stavaka za koje se ovdje generiraju slučajni brojevi, također je na istom listu izdvojen i redak gdje se generiraju slučajni brojevi za udio poslovnih rashoda u poslovnim prihodima. Promatrajući prethodne godine možemo primijetiti da poslovni rashodi uglavnom iznose oko 85 do 115 posto poslovnih prihoda. Zbog toga sam odlučio ovdje iskazati poslovne rashode kao dio poslovnih prihoda, a taj udio se također simulira.

Bilanca	Aktiva
	DUGOTRAJNA IMOVINA
	Nematerijalna imovina
	Materijalna imovina
	KRA TKOTRAJNA IMOVINA
	Potraživanja
	Zalihe
	Pasiva
	KAPITAL I REZERVE
	Zadržana dobit ili preneseni gubitak
	Dobit ili gubitak poslovne godine
	DUGOROČNE OBVEZE
	KRA TKOROČNE OBVEZE
Račun dobiti i gubitka	Poslovni prihodi
	Prihodi od prodaje (po kvartalima)
	Ostali poslovni prihodi
	Poslovni rashodi (*godisnje)
	Financijski prihodi
	Financijski rashodi
	Ukupni prihodi
	Ukupni rashodi
	Dobitak ili gubitak prije oporezivanja
	Porez na dobit
	Dobit ili gubitak razdoblja

Izveštaj o novčanim tijekovima	NOVČANI TIJEK OD POSLOVNIH AKTIVNOSTI
	1. Dobit prije poreza
	2. Amortizacija (*godisnje)
	3. Povećanje kratkoročnih obveza
	4. Smanjenje kratkotrajnih potraživanja
	5. Smanjenje zaliha
	6. Ostalo povećanje novčanog tijeka
	I. Ukupno povećanje novčanog tijeka od poslovnih aktivnosti (001 do 006)
	1. Smanjenje kratkoročnih obveza
	2. Povećanje kratkotrajnih potraživanja
	3. Povećanje zaliha
	4. Ostalo smanjenje novčanog tijeka
	II. Ukupno smanjenje novčanog tijeka od poslovnih aktivnosti (008 do 011)
	A1) NETO POVEĆANJE NOVČANOG TIJEKA OD POSLOVNIH
	A2) NETO SMANJENJE NOVČANOG TIJEKA OD POSLOVNIH
	NOVČANI TIJEK OD INVESTICIJSKIH AKTIVNOSTI
	III. Ukupno novčani primici od investicijskih aktivnosti (015 do 019)
	IV. Ukupno novčani izdaci od investicijskih aktivnosti (021 do 023)
	B1) NETO POVEĆANJE NOVČANOG TIJEKA OD INVESTICIJSKIH
	B2) NETO SMANJENJE NOVČANOG TIJEKA OD INVESTICIJSKIH
	NOVČANI TIJEK OD FINANCIJSKIH AKTIVNOSTI
	C1) NETO POVEĆANJE NOVČANOG TIJEKA OD FINANCIJSKIH
	C2) NETO SMANJENJE NOVČANOG TIJEKA OD FINANCIJSKIH
	Ukupno povećanje novčanog tijeka (013 – 014 + 025 – 026 + 037 – 038)
	Ukupno smanjenje novčanog tijeka (014 – 013 + 026 – 025 + 038 – 037)
	Novac i novčani ekvivalenti na početku razdoblja
	Povećanje novca i novčanih ekvivalenata
	Smanjenje novca i novčanih ekvivalenata
	Novac i novčani ekvivalenti na kraju razdoblja

Slike 10 i 11: Sadržaj tablice s postavkama simulacije (vlastita izrada – isječak iz modela u Excelu)

3.5. Rezultati simulacije i tumačenje rezultata

Sljedeća slika prikazuje tablicu u Excelu sa projiciranim vrijednostima nastalima na temelju slučajnih brojeva objašnjenih u prethodnom poglavlju. Na slici je prikazana bilanca, račun dobiti i gubitka, te dio izvještaja o novčanim tijekovima. Godine koje su vidljive na isječku su 2017. koja nije simulirana, već služi da se prema njoj računaju sljedeće godine i 2018. godina koja je prva godina projekcije. Strelicama je na slici prikazan odnos nekoliko stavaka u Excelu. Kao i u prethodnoj tablici i ovdje su plavom bojom označene stavke koje se dobivaju simulacijom. Ako zbrojimo prikazane stavke unutar bilance za dugotrajnu ili kratkotrajnu imovinu ne dobivamo iste iznose koji se nalaze pod stavkama dugotrajna imovina i kratkotrajna imovina. Razlog tome je što ovi izvještaji ne prikazuju cijeli izvještaj, već samo dijelove koji su najbitniji za simulaciju. Neke stavke simuliraju se samo kako bi se otprilike vidjelo što se od njih može očekivati na temelju prošlih godina i kakav će biti odnos tih stavaka sa nekim drugim simuliranim stavkama.

Stavka zadržana dobit ili preneseni gubitak računa se tako da se za prethodnu godinu zbroji iznos te stavke i dobit ili gubitak poslovne godine. Tako dobiveni rezultat se računa samo iz 4. kvartala u godini i ostavlja se isti za svaki kvartal unutar godine.

Simulacijom dobivene vrijednosti za kratkoročne obveze, potraživanja i zalihe iz bilance koriste se u izvještaju o novčanim tijekovima za izračun stavaka povećanje kratkoročnih obveza, smanjenje kratkoročnih obveza, povećanje kratkoročnih potraživanja, smanjenje kratkoročnih potraživanja, povećanje zaliha i smanjenje zaliha.

		2017				2018			
		1	2	3	4	1	2	3	4
Bilanca	Aktiva								
	DUGOTRAJNA IMOVINA	1.662.412.013	1.423.256.696	1.261.651.552	1.288.701.453	1.647.083.080	1.374.828.878	1.208.619.434	1.241.826.679
	Nematerijalna imovina	12.247.155	12.348.460	12.328.503	12.636.163	10.958.176	11.501.942	11.269.761	12.042.012
	Materijalna imovina	1.616.809.527	1.381.575.457	1.220.851.185	1.272.587.665	1.552.819.061	1.330.526.830	1.188.853.096	1.221.160.394
	KRA TKOTRAJNA IMOVINA	112.752.004	112.870.047	133.499.042	117.848.578	115.560.320	108.824.695	131.446.794	112.196.002
	Potraživanja	5.084.885	17.429.427	25.767.700	49.871.549	5.452.541	18.171.013	26.197.158	48.571.514
	Zalihe	38.705.888	33.765.810	29.291.715	21.298.060	42.710.802	39.312.892	33.151.946	23.377.587
	Pasiva								
	KAPITAL I REZERVE	573.501.390	556.750.267	545.994.183	557.885.979	555.531.794	528.774.058	521.990.741	532.094.609
	Zadržana dobit ili preneseni gubitak	-77.539.797	-68.114.636	-65.186.185	-72.692.111	8.631.233	8.631.233	8.631.233	8.631.233
Račun dobiti i gubitka	Dobit ili gubitak poslovne godine	2.837.288	40.738.018	42.520.468	81.323.344	0	0	0	0
	DUGOROČNE OBVEZE	877.142.937	797.118.032	759.842.542	418.814.809	830.963.154	760.880.661	732.121.041	395.902.902
	KRA TKOROČNE OBVEZE	302.791.274	180.941.086	96.084.837	412.322.815	287.261.042	184.481.975	86.904.207	371.271.922
	Poslovni prihodi	99.249.610	217.770.153	309.685.658	521.383.059	112.480.696	237.767.595	348.289.659	570.009.214
	Prihodi od prodaje (po kvartalima)	93.251.646	186.447.549	265.107.833	365.504.181	105.761.821	207.311.998	301.856.095	425.272.158
	Ostali poslovni prihodi	5.997.964	31.322.604	44.577.825	155.878.878	6.718.875	30.455.597	46.433.564	144.737.056
	Poslovni rashodi (*godisnje)	85.814.229	180.402.282	265.266.655	427.149.012	111.094.044	239.783.991	357.985.680	602.496.121
	Financijski prihodi	3.857.945	40.022.827	48.959.121	55.923.127	3.751.066	39.431.744	59.357.366	57.613.933
	Financijski rashodi	14.456.038	36.652.680	50.857.656	68.962.081	14.814.254	38.463.997	52.694.748	73.866.968
	Ukupni prihodi	103.107.555	257.792.980	358.644.779	577.306.186	116.231.762	277.199.338	407.647.026	627.623.147
NOVČANI TLJEK OD POSLOVNIH AKTIVNOSTI	Ukupni rashodi	100.270.267	217.054.962	316.124.311	496.111.093	125.908.298	278.247.987	410.680.428	676.363.089
	Dobitak ili gubitak prije oporezivanja	2.837.288	40.738.018	42.520.468	81.195.093	-9.676.536	-1.048.649	-3.033.402	-48.739.942
	Porez na dobit	510.712	7.332.843	7.653.684	14.615.117	-1.741.776	-188.757	-546.012	-8.773.190
	Dobit ili gubitak razdoblja	2.326.576	33.405.175	34.866.784	66.579.976	0	0	0	0
	1. Dobit prije poreza	2.837.288	40.738.018	42.520.468	81.161.354	-9.676.536	-1.048.649	-3.033.402	-48.739.942
	2. Amortizacija	20.032.911	40.657.280	55.323.067	2.811.065	12.031.227	26.924.929	36.601.318	1.595.466
	3. Povećanje kratkoročnih obveza	0	0	0	0	0	0	0	284.367.715
	4. Smanjenje kratkotrajnih potraživanja	18.944.020	6.599.478	0	0	44.419.008	0	0	0
	5. Smanjenje zaliha	0	0	2.136.926	8.901.831	0	3.397.910	6.160.946	9.774.359

Slika 12: Isječak iz tablice sa simulacijom dobivenim projekcijama (vlastita izrada – isječak iz modela u Excelu)

S dane slike vidljivo je i kako prema dolje sve manje stavaka ima plavu pozadinu – jer se najveći dio simulacije odnosi na bilancu i račun dobiti i gubitka. Tako se stavkama iz Izvještaja o novčanim tijekovima, te stavkama iz računa dobiti i gubitka kao što su ukupni prihodi ili ukupni rashodi daje pozadina. Možemo vidjeti što je u kojoj mjeri utjecalo na krajnji rezultat i od čega se on sve sastoji.

Sljedeća slika prikazuje dio iste tablice u kojem je vidljiv konačni rezultat modela: povećanje i smanjenje novca i novčanih ekvivalenata u određenoj godini, te novac i novčani ekvivalenti na kraju te godine. Ispod tablice Izvještaja o novčanim tijekovima, osjenčano svijetloplavom bojom, prikazan je diskontirani novčani tok. Diskontna stopa po kojoj je on računat je 10%, što je relativno visoka stopa, međutim takva je izabrana zbog velikog rizika koji postoji u prijevozu brodovima. Simulacija u većini slučajeva izvođenja prikazuje porast novčanih ekvivalenata u projiciranim godinama. Ispod prikaza diskontiranog novčanog tijeka prikazan je i izračun dionica. U primjeru sa slike vidimo da je projicirana cijena dionice za 2022. godinu 508,07kn, što je povećanje u odnosu na prosječnu cijenu iz 2018. godine koja iznosi oko 460kn.

C2) NETO SMANJENJE NOVČANOG TIJEKA OD FINANCIJSKIH AKTIVNOSTI (036-030)	58.457.581	243.889.749	364.482.145	10.538.388	55.126.815	209.166.340	323.437.282	9.812.231
Ukupno povećanje novčanog tijeka (013 – 014 + 025 – 026 + 037 – 038)	0	0	17.900.193	0	1.169.654	118.709.092	279.023.469	288.622.769
Ukupno smanjenje novčanog tijeka (014 – 013 + 026 – 025 + 038 – 037)	660.203	7.896.624	0	40.664.099	105.938.628	275.554.527	350.689.628	55.698.630
Novac i novčani ekvivalenti na početku razdoblja	69.239.434	69.239.434	60.239.434	57.180.009	16.515.880	16.515.880	16.515.880	16.515.880
Povećanje novca i novčanih ekvivalenata	0	0	17.900.193	0	0	0	0	232.924.139
Smanjenje novca i novčanih ekvivalenata	660.203	7.896.624	0	40.664.129	104.768.974	156.845.435	71.666.159	0
Novac i novčani ekvivalenti na kraju razdoblja	68.579.231	61.342.810	78.139.627	16.515.880	-88.253.094	-140.329.555	-55.150.279	249.440.019
Diskontirani novčani tok								226.763.654
Diskontna stopa:	10%							
Diskontirani novčani tijek na kraju 2022:	708.758.201							
Broj dionica	1395000							
Cijena dionice=	508,07 kn							

Slika 13: Isječak iz tablice sa simulacijom dobivenim projekcijama koji prikazuje rezultat simulacije po godinama (vlastita izrada – isječak iz modela u Excelu)

Kako bi se prikazalo više iteracija simulacije odjednom u zadnjem listu Excela modela what-if analizom prikazao sam diskontirani novčani tijek za 2022. godinu i pripadajuću cijenu dionica u 200 ponavljanja. What-if analiza je Excelova ugrađena funkcija koja u ovom primjeru omogućava da se sve simulacije koje dovode do krajnjeg rezultata (diskontirani novčani tijek u 2022. godini) ponove željeni broj puta te da se taj rezultat prikaže. Slika 14 prikazuje nekoliko iteracija dobivenih what-If analizom. Za svaku od tih iteracija ponovilo se sljedeće:

1. Simulirane su postotne promjene za 21 vrijednost u 4 kvartala 5 godina, po 100 puta svaki kvartal
2. Izračunat je prosjek simuliranih promjena za svaki projicirani kvartal
3. Izračunat je iznos stavke na temelju prošle vrijednosti i simulirane promjene
4. Izračunate su stavke koje se ne simuliraju
5. Konačni rezultat pribrojen je rezultatu protekle godine
6. Novčani tijek na kraju godine je diskontiran
7. Izračunata je cijena dionica


Slika 15 pokazuje kumulativ i frekvenciju rasporeda rezultata simulacije u cjenovne razrede od 300 do 1000kn. I ovdje je vidljiva normalna distribucija sa najvećim dijelom vrijednosti oko sredine tablice, to jest oko iznosa cijena od 500, 550 i 600 kuna po dionici. Slika 16 je grafički prikaz iste simulacije na kojem se ta distribucija još ljepše može vidjeti.

	DCF 2022:	Cijena:
prosjeak	699.898.685	502
1	563.611.579	404
2	761.871.537	546
3	669.114.654	480
4	506.589.371	363
5	715.340.955	513
6	563.611.579	404
7	717.114.478	514
8	659.296.747	473
9	640.158.680	459
10	714.231.384	512
11	773.601.687	555
12	764.154.599	548
13	844.318.438	605
14	439.305.746	315
15	654.338.082	469
16	606.840.287	435
17	915.887.808	657
18	621.784.363	446
19	752.968.181	540
20	697.183.357	500
21	721.863.878	517
22	730.172.416	523
23	668.714.284	479
24	814.259.897	584
25	647.073.788	464

Slika 14: Prvih 25 iteracija What-If analize kojom je simulacija ponovljena više puta (vlastita izrada – isječak iz modela u Excelu)

Razredi	Kumulativ	Frekvencija
300	4	4
350	11	7
400	35	24
450	84	49
500	153	69
550	217	64
600	268	51
650	291	23
700	299	8
750	299	0
800	300	1
850	300	0
900	300	0
950	300	0
1000	300	0

Slika 15: Tablica koja prikazuje Kumulativ i Frekvenciju cijena dionica dobivenih u What-If analizi, po razredima od 50kn (vlastita izrada – isječak iz modela u Excelu)




Slika 16: Grafički prikaz cijena dionica dobivenih What-If analizom (vlastita izrada – isječak iz modela u Excelu)

Cijena dionica sredinom 2018. godine iznosila je oko 460 kuna. Prema grafikonu sa slike 16 vidimo da se je u većini slučajeva simulacijom projicirana cijena blizu te vrijednosti ili veća. Kada bi ovaj model koristili za odlučivanje o investiranju ovo bi bilo zeleno svjetlo za kupnju dionica. Isto tako možemo zaključiti da bi dionice bilo najbolje prodati kada njihova cijena prelazi 500 ili 600 kuna po dionici, jer model u jako malo slučajeva predviđa da će cijena biti veća od takve.

3.6. Dijagram tijeka simulacije

Sljedeći dijagram prikazuje veze između triju financijskih izvještaja u simulaciji. Iz dijagrama je vidljivo da se neki dijelovi izvještaja dobivaju u isto vrijeme, a ostali se računaju naknadno – kombinacijom prije simuliranih vrijednosti. Tako npr. u listu *Račun dobiti i gubitka* simulacijom dobivamo prihode i rashode od poslovanja i financijske prihode i rashode, iz čega se izračunava dobit na kraju razdoblja. Ta dobit zajedno sa promjenama zaliha, kratkoročnih potraživanja i kratkoročnih obveza (izračunatih iz bilance) koristi se u izvještaju o novčanim tokovima za izračun smanjenja ili povećanja novčanog tijeka.

Ono što dijagram pokazuje također možemo vidjeti i u realnom poslovanju. Stavke koje se u modelu računaju iz simuliranih stavaka u izvještajima također se i u poslovanju računaju. A kod kreiranja financijskih izvještaja često se u više izvještaja koriste iste vrijednosti ili se vrijednosti iz jednog izvještaja koriste za izračun vrijednosti u drugim izvještajima.



Slika 17: Prikaz tijeka simulacije (vlastita izrada u online alatu bpmn.io)

4. Zaključak

Glavni cilj ovog rada bio je projicirati izvještaj o novčanim tijekovima poduzeća. Kako bi to postigao analizirao sam prethodne godine poslovanja. Početni model koji sam sastavio sadržavao je samo izvještaje o novčanim tijekovima. Međutim oni nisu davali previše detalja, niti kontekst vrijednostima koje u njima vidimo. Zbog toga sam u model dodatno ukomponirao i bilancu i račun dobiti i gubitka, izabравši iz istih stavke koje su davale dovoljno jasnu sliku o samom izvještaju, te o stavkama koje se pojavljuju u Izvještaju o novčanim tijekovima, a računaju se temeljem stavaka iz ovih izvještaja. Analiziranje i simuliranje cjelovite bilance i računa dobiti i gubitka vjerojatno bi dalo detaljniju sliku o tome kuda simulacija predviđa da će se poduzeće kretati. Međutim to ne bi uvelike utjecalo na ovdje dobiveni rezultat.

Drugi način za proširiti model, te ga vjerojatno učiniti i točnijim bio bi koristeći Baltic Dry Index. Problem kod tog pristupa bio bi taj što je Baltic Dry Index uvelike uvjetovan političkim promjenama i globalnim promjenama tržišta. Sama analiza prošlih vrijednosti Baltic Dry Indexa teško da bi mogla biti odrađena bez propusta. Čak i kada bi projekcija Baltic Dry Indexa uspjela, te kada bi iz prošlih vrijednosti bile eliminirane vrijednosti koje dovode do naglih skokova ili nerealnih predviđanja, nikako ne bi bilo moguće odrediti političke događaje iz budućnosti koji će zasigurno utjecati na Baltic Dry Index.

Zaključujem da ovaj model predviđa porast vrijednosti dionica Atlantske Plovidbe, temeljem analize financijskih izvještaja za protekle godine i simulacijom vrijednosti za sljedeće. Preciznost ovog modela u odnosu na stvarne rezultate utoliko se smanjuje koliko postoje utjecaji s političkog ili svjetskog trgovinskog spektra. Pretpostavljam da bi se kod stabilnog Baltic Dry Indexa i bez pojave krize na tržištu projicirane vrijednosti u sljedećim godinama trebale nalaziti blizu stvarnim rezultatima poduzeća.

Izrađujući ovaj model stekao sam detaljnije znanje o financijskim izvještajima, naučio sa kako izvoditi simulacije u MS Excelu, te otkrio koliko je puno informacija o poslovanjima velikih poduzeća dostupno on-line.

Zahvaljujem se svojem mentoru Dušanu Mundaru, jer osim što mi je detaljno i jasno objasnio pojedinosti koje su mi trebale u radu, također se potrudio da ovaj rad ima smisla u realnom svijetu, bude zanimljiv, te mi je omogućio da shvatim kako stotine brojeva u Excelu imaju svoje značenje te ih tako i treba promatrati.

Popis literature

Investopedia (2018). *Baltic Dry Index*, Preuzeto 5. lipnja 2018., s
https://www.investopedia.com/terms/b/baltic_dry_index.asp

Martin, W.(2018). *A 'canary down the coal mine' that predicted the 2008 crisis is signalling another crash*, Preuzeto 10. lipnja 2018., s
<http://uk.businessinsider.com/baltic-dry-index-falls-to-lowest-level-in-history-2016-1>

Render, B. *Quantitative Analysis for Management*, Prentice Hall, 2000
Slideshare (2018). *Chartering Terms Definition*, Preuzeto 5. lipnja 2018., s
<https://www.slideshare.net/gior087/chartering-terms-definition>

Wikipedia(2018). *Atlantska plovdba*, Preuzeto 1. lipnja 2018.,s
https://hr.wikipedia.org/wiki/Atlantska_plovdba

Grupa Atlantska plovdba(2013). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-III 2013. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2013). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-VI 2013. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2013). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-IX 2013. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2013). *Revidirani izvještaj posloводства za razdoblje I-XII 2013. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2014). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-III 2014. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2014). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-VI 2014. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2014). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-IX 2014. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2014). *Revidirani izvještaj posloводства za razdoblje I-XII 2014. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2015). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-III 2015. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2015). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-VI 2015. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2015). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-IX 2015. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2015). *Revidirani izvještaj posloводства za razdoblje I-XII 2015. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2016). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-III 2016. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2016). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-VI 2016. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2016). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-IX 2016. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2016). *Revidirani izvještaj posloводства za razdoblje I-XII 2016. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2017). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-III 2017. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2017). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-VI 2017. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2017). *Nerevidirani konsolidirani financijski izvještaj za razdoblje I-IX 2017. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Grupa Atlantska plovdba(2017). *Revidirani izvještaj posloводства za razdoblje I-XII 2017. godine*, Preuzeto 25. svibnja 2018. s
<http://www.zse.hr/default.aspx?id=10006&dionica=63>

Popis slika

Slika 1: Graf s prikazom Baltic Dry Index-a i Obujma globalne trgovine. (izvor: Thompson Datastream, Capital Economics, preuzeto s http://uk.businessinsider.com/baltic-dry-index-falls-to-lowest-level-in-history-2016-1 , dostupno 11.7.2018.).....	4
Slika 2: Graf koji prikazuje promjene vrijednosti Baltic Dry Index-a (preuzeto s: https://tradingeconomics.com/commodity/baltic , dostupno 11.7.2018.).....	5
Slika 3: Porast prosjeka po godinama u Izvještajima o novčanim tijekovima (vlastita izrada – isječak iz modela u Excelu).....	16
Slika 4: Balance iz godine 2015 po kvartalima (vlastita izrada – isječak iz modela u Excelu).....	17
Slika 5: Balance iz godine 2017, s postotnim promjenama po kvartalima (vlastita izrada – isječak iz modela u Excelu).....	18
Slika 6: Račun dobiti i gubitka iz godine 2014: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)	19
Slika 7: Račun dobiti i gubitka iz godine 2015: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)	19
Slika 8: Račun dobiti i gubitka iz godine 2016: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)	20
Slika 9: Račun dobiti i gubitka iz godine 2017: postotne promjene po kvartalima (vlastita izrada – isječak iz modela u Excelu)	20
Slike 10 i 11: Sadržaj tablice s postavkama simulacije (vlastita izrada – isječak iz modela u Excelu).....	22
Slika 12: Isječak iz tablice sa simulacijom dobivenim projekcijama (vlastita izrada – isječak iz modela u Excelu)	24
Slika 13: Isječak iz tablice sa simulacijom dobivenim projekcijama koji prikazuje rezultat simulacije po godinama (vlastita izrada – isječak iz modela u Excelu)	25
Slika 14: Prvih 25 iteracija What-If analize kojom je simulacija ponovljena više puta (vlastita izrada – isječak iz modela u Excelu)	26
Slika 15: Tablica koja prikazuje Kumulativ i Frekvenciju cijena dionica dobivenih u What-If analizi, po razredima od 50kn (vlastita izrada – isječak iz modela u Excelu) 26	
Slika 16: Grafički prikaz cijena dionica dobivenih What-If analizom (vlastita izrada – isječak iz modela u Excelu)	27

Popis tablica

Tablica 1: Sadržaji listova koji čine excel datoteku modela	14
---	----

Prilog

Projekcija simulacijom za Atlantsku plovidbu, Excel datoteka vlastite izrade.